

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Maja Režonja

PRIJEDLOZI OPTIMIRANJA ZALIHA POSTPRODAJE
AUTOMOBILSKE INDUSTRIJE

ZAVRŠNI RAD

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
ODBOR ZA ZAVRŠNI RAD

Zagreb, 25. travnja 2017.

Zavod: Zavod za transportnu logistiku
Predmet: Upravljanje zalihama

ZAVRŠNI ZADATAK br. 3963

Pristupnik: Maja Režonja (0135207157)
Studij: Inteligentni transportni sustavi i logistika
Smjer: Logistika

Zadatak: Prijedlozi optimiranja zaliha postprodaje automobilske industrije

Opis zadatka:

U radu je potrebno objasniti specifičnosti artikala/robe u postprodaji automobilske industrije s osvrtom na upravljanje zalihama. Navesti prisutne poteškoće pri upravljanju zalihama s navedenim artiklima te prikazati na primjeru iz prakse kojim se postupcima mogu optimirati zalihe u postprodaji automobilske industrije.

Zadatak uručen pristupniku: 28. travnja 2017.

Mentor:



prof. dr. sc. Mario Šafran

Predsjednik povjerenstva za
završni ispit:



Sveučilište u Zagrebu
Fakultet prometnih znanosti

ZAVRŠNI RAD

**PRIJEDLOZI OPTIMIRANJA ZALIHA POSTPRODAJE
AUTOMOBILSKE INDUSTRIJE**

**AUTOMOTIVE PARTS INVENTORY OPTIMIZATION
OPTIONS**

Mentor: prof. dr. sc. Mario Šafran

Studentica: Maja Režonja

JMBAG: 0135207157

Zagreb, rujan 2017.

PRIJEDLOZI OPTIMIRANJA ZALIHA POSTPRODAJE AUTOMOBILSKE INDUSTRIJE

SAŽETAK

Optimiranje zaliha vodeći je zadatak svake tvrtke. Postiže se analizama prema raznim kriterijima kao što su opseg potrošnje, kontinuitet potrošnje ili rizici opskrbe. U završnom radu obrađeni su modeli i analize koje pomažu pri optimiranju zaliha. Cilj svake industrije pa tako i automobilske je poboljšati efikasnost i svesti troškove na minimalnu razinu, a da pritom razina usluge koju pruža korisnicima ostane na zadovoljavajućoj razini, kako bi se zadržala konkurentnost na tržištu. Zalihe u postprodaji automobilske industrije predstavljaju osnovni problem svake tvrtke koja se bavi njihovom distribucijom i prodajom. Rješenje problema postiže se pravilnim optimiranjem zalihama, prikazanom u posljednjem poglavlju završnog rada, informatizacijom cjelokupnog poslovanja i razvijanjem raznih sustava optimiranja zaliha.

KLJUČNE RIJEČI: zalihe; automobilska industrija; optimiranje.

AUTOMOTIVE PARTS INVENTORY OPTIMIZATION OPTIONS

SUMMARY

Inventory optimization is the guiding task of any company. Analyze are obtained according to various criteria such as the range of consumption, the continuity of consumption or the risks of supplier activity. In the final paper, models and analyzes that helps to optimize inventory are processed. The goal of every industry and even the automotive are to improve efficiency and reduce costs to a minimum, while maintaining the level of service provided for users at a satisfactory level in order to maintain market competitiveness. Automotive parts supplies are the basic problem of any company that deals with their distribution and sales. The solution to the problem is achieved through a proper inventory optimization, as shown in the last chapter of the final work, by informatiozation the entire business and by developing various inventory optimization systems.

KEYWORDS: supply; automotive; supply optimization.

Sadržaj:

1. UVOD	1
2. OSNOVNE ZNAČAJKE UPRAVLJANJA ZALIHAMA	2
2.1. Tradicionalni modeli upravljanja zalihama	3
2.2. Model ekonomske količine nabave – EOQ.....	5
2.3. Suvremeni modeli upravljanja zalihama	7
2.3.1. Planiranje materijalnih potreba – MRP	8
2.3.2. Planiranje resursa proizvodnje – MRP II	9
2.3.3. Kanban i sustav „Just in time“	9
2.3.4. Ostali modeli upravljanja zalihama.....	11
3. MOGUĆNOSTI OPTIMIRANJA ZALIHA.....	12
3.1. ABC analiza.....	12
3.2. XYZ analiza.....	14
3.3. Primjena kombinacije ABC i XYZ analize	16
4. SPECIFIČNOSTI UPRAVLJANJA ZALIHAMA POSTPRODAJE AUTOMOBILSKA INDUSTRIJE	18
4.1. Primjena ERP sustava pri optimizaciji zaliha.....	19
4.2. Prednosti i nedostaci ERP sustava.....	20
5. OPTIMIRANJE ZALIHA STUDIJA SLUČAJA	22
5.1. Provedba ABC analize.....	24
5.2. Provedba XYZ analize.....	28
5.3. Provedba unakrsne ABC/XYZ analize.....	31
Literatura	34
Popis kratica	36
Popis slika	37
Popis tablica	38

1. UVOD

Automobilska industrija jedna je od vodećih industrija na globalnom tržištu. Tvrtke koje se bave postprodajom automobilske industrije generiraju velik broj zaliha na svojim skladištima. Zalihe robe jedan su od glavnih izvora prihoda svake tvrtke, kako donose prihode tako i njihovo držanje i cijeli proces nabave iziskuje određene troškove. Previše nepotrebnih zaliha može dovesti do velikih financijskih gubitaka tvrtke te se iz tog razloga u prvi plan stavlja optimizacija zaliha.

Tema ovog završnog rada je „Prijedlozi optimiranja zaliha postprodaje automobilske industrije“. Rad sadrži šest poglavlja:

1. Uvod
2. Osnovne značajke upravljanja zalihama
3. Mogućnosti optimiranja zaliha
4. Specifičnosti upravljanja zalihama postprodaje automobilske industrije
5. Optimiranje zaliha studija slučaja
6. Zaključak.

od kojih četiri glavna daju odgovor na temu samog rada.

U drugom poglavlju definiran je pojam upravljanja zalihama, glavne metode i modeli koji to omogućuju te prikaz kako se upravljanje zalihama razvijalo tokom vremena.

Treće poglavlje donosi analize koje se primjenjuju pri optimizaciji zaliha s obzirom na kriterije po kojima se zalihe razvrstavaju.

Četvrto poglavlje prikazuje osvrt na zalihe u postprodaji automobilske industrije i razvitak široko primjenjivog informacijskog sustava ERP, bez kojeg optimizacija zaliha u takvoj vrsti poslovanja bi bila gotovo nemoguća.

U petom poglavlju provodi se analiza zaliha prema stvarnim podacima potražnje za istima u prethodnom razdoblju, temeljem unakrsne ABC/XYZ analize te su izneseni zaključci doneseni na temelju izračuna.

2. OSNOVNE ZNAČAJKE UPRAVLJANJA ZALIHAMA

Među glavnim i vodećim zadacima logističkog menadžmenta nalazi se upravljanje zalihama. Mnoge tvrtke susreću se s problemima koji otežavaju pronalaženje optimalne politike upravljanja zaliha: nepredvidivošću potražnje, dugim vremenima isporuke, nepouzdanim procesom dobave, velikim brojem artikala, te kratkim vremenom potražnje za određeni proizvodom.[1]

Svi tipovi zaliha zahtijevaju odgovarajuće mehanizme upravljanja. Najbolje upravljanje poslovnim procesom zahtijeva usklađivanje svih proizvodnih, nabavnih i distribucijskih djelatnosti unutar logističkog lanca. Ono stoga nije jednostavan problem pojedinog sudionika, već problem koji za svako pojedino rješenje traži informacije na razini cijelog sustava.[1]

Temeljna ideja logističkog upravljanja zalihama je da one budu što manje, ali uvijek dovoljne za ispunjavanje potreba kupaca, potrošača i korisnika. Prevelike količine zaliha rezultiraju visokim troškovima držanja, a premalena količina zaliha implicira brojne probleme, poteškoće i štetne posljedice u proizvodnji, trgovini i distribuciji.[2]

Učinkovito upravljanje zalihama ovisi najviše o:

- primjeni suvremenih metoda planiranja i razvitka sustava isporuke “točno na vrijeme”
- primjeni kompjuterske tehnike, komunikacijskih veza i informacijske tehnologije
- primjeni metoda prognoziranja i planiranja ponude i potražnje na tržištu
- edukaciji i svijesti svih zaposlenih o potrebi držanja što nižih zaliha
- brzini kretanja transportnih sredstava, roba i ljudi kroz logistički sustav
- kamatnoj stopi za financiranje zaliha i poreznoj politici prema zalihama.[3]

S obzirom na primjenu metoda planiranja i modela upravljanje zalihama podijeljeno je na:

- primjenu tradicionalnih modela upravljanja
- primjenu suvremenih modela upravljanja.

Modeli smanjuju potrebu za držanjem velike količine zaliha, a istovremeno i veličinu ukupnih troškova. Kao kriteriji koji uvjetuju izbor modela i metoda za svaki pojedini slučaj, mogu se uzeti u obzir faktori kao što su na primjer, veličina tvrtke ili opseg njenog

poslovanja, izvori nabave, uvjeti isporuke, kapacitet skladišta i drugo. U najvećem broju slučajeva kao osnovni kriterij uzima se kriterij troška. Onaj model koji osigurava minimalne ukupne troškove zaliha pomaže u određivanju optimalne strategije upravljanja zalihama.[4]


2.1.Tradicionalni modeli upravljanja zalihama

Prvi model za utvrđivanje optimalne količine nabavke postavljen je još 1915. godine. Postavio ga je F. Harris, rješavajući optimalnu količinu nabave pomoću infinitezimalnog računa. Model je statičan i vrlo jednostavan. Temelji se na slijedećim pretpostavkama: 1. potražnja za robom je ravnomjerna i unaprijed poznata; 2. roba se naručuje po isteku zaliha, roba stiže na vrijeme i naručuje se u jednakim vremenskim razdobljima; 3. ne uzimaju se u obzir nikakva ograničenja kao što su primjerice veličina skladišta, raspoloživi financijski resursi i slično. Od tada do danas teorija zaliha se neprekidno razvija, a broj modela za upravljanje zalihama svakodnevno se povećava.[4]

Prema načinu utvrđivanja trenutka nabave razlikujemo tri osnovna modela: kontinuirani sustav nadzora razine zaliha (eng. economic order quantity, EOQ, Q – model), periodični sustav nadzora razine zaliha (eng. periodic system, fixed – order interval system, P – model) i adaptivni sustav nadzora. Ako je podloga sustava nadzora razine zaliha orijentirana na količinu zaliha, onda je riječ o kontinuiranom sustavu nadzora, a ako je podloga strategija nabavljanja orijentirana vremenom, onda je riječ o periodičnom sustavu nadzora zaliha. Kada je u pitanju povremena ili sezonska potrošnja predmeta rada, koristimo adaptivni sustav nadzora.[5]

Kontinuirani sustav nadzora razine zaliha kod svakog predmeta rada ispituje da li je zaliha pala na razinu signalne, sigurnosne ili minimalne zalihe, odnosno točke ponovne nabave te se naručuje nova količina. Ove količine predstavljaju onu količinu zalihe koliko je procijenjeno prema potražnji tijekom vremena isporuke.[6]


Slika 1. prikazuje kretanje zaliha kontinuiranim sustavom, pretpostavka je da se radi o kontinuiranoj potrošnji za koju je utvrđena signalna zaliha. Ako bismo kad zalihe dostignu signalnu zalihu samo izdavali robu, u određenom vremenu zalihe bi bile iscrpljene. Da se to ne dogodi, valja pravovremeno ispostaviti narudžbu, tj. utvrditi kod kojeg stanja zalihe treba započeti period nabave.[7]



Slika 1. Kretanje zaliha u kontinuiranom sustavu nadzora razine zaliha, Q - model kontinuiranom sustavu nadzora, [7]

Periodični sustav nadzora razine zaliha koristi se u slučajevima kada je nabava moguća samo u zadanim rokovima (ciklički), koji odgovaraju ritmu isporuke dobavljača ili ritmu potreba vlastite proizvodnje, a prema kojima se utvrđuje i rok nabave. Najjednostavniji periodični sustav nadzora je onaj kod kojeg se u fiksnim vremenskim intervalima (na primjer tjedno, mjesečno) preispituje zaliha i naručuje ona količina koja je potrebna da se dostigne maksimalna količina zaliha na stanju.

Slika 2. prikazuje kretanje zaliha periodičnim sustavom, količina nabave odgovara razlici gornje granice i ostatka zalihe u prošlom planskom periodu. Zbog nejednake potrošnje je vrijeme u kojem zaliha mora pokriti potrebe, u pojedinim ciklusima različito, pa valja određivati rok isporuke tako da se pokriju prognozirane potrebe te sigurnosna zaliha i u narednom periodu nabavljanja.[8]



Slika 2. Kretanje zaliha u periodičnom sustavu nadzora razine zaliha, P – model, [7]

Kontinuirani i periodični sustavi nadzora primjenjuju se u slučajevima približno konstantne potrošnje u dužem vremenu i ne može ih se prilagoditi kratkoročnim promjenama potreba, kao što je kod sezonske potrošnje ili potreba koje se reprezentiraju linijom trenda. U takvim se slučajevima koriste adaptivni sustavi nadzora. Trenutak i količina nabave normiraju se u dužem vremenu u skladu s prognoziranim potrebama. Na taj način se sprječavaju situacije iscrpljivanja zaliha ili stvaranja prekonormnih zaliha.

Ako dolazi do određenih promjena potražnje, onda se mijenjaju količine nabave ili pomaci u rokovima nabave. Razlozi za pomak rokova na ranije datume mogu biti:

- veće povećanje potrošnje od očekivane nakon zadnje isporuke
- prognoza povećanja potrošnje
- u zadnjoj pošiljci isporučena je manja količina nego što se očekivalo
- dolazak do većeg loma ili kvara u pošiljci što se očekuje.[8]

2.2. Model ekonomske količine nabave – EOQ

Ekonomska količina nabave EOQ je jedan od tradicionalnih modela upravljanja zalihama, zasnovan na kontinuiranom sustavu nadzora. Definiran je jednadžbom koja određuje idealnu količinu narudžbe koju tvrtka treba kupiti s obzirom na određeni trošak

proizvodnje, potražnje i drugih faktora. Na taj način osiguravaju se najniži troškovi u nabavi i držanju zaliha koji utječu na cjelokupno poslovanje tvrtke.

Jednadžba EOQ glasi:

$$EOQ = \frac{\sqrt{2 \cdot D \cdot C_0}}{C_h}, \quad (1)$$

gdje je: EOQ – ekonomska količina nabave

D – prognoza potražnje u periodu vremena (mjesec, godina)

C₀ – trošak po nabavi

C_h – trošak držanja zaliha.[6]


Model je jednostavan za primjenu i temelji se na slijedećim pretpostavkama:

- potražnja je poznata i događa se u relativno konstantnim periodima
- roba ima dovoljno dug rok trajanja
- cijela narudžba dolazi u jednoj isporuci
- vrijeme isporuke (vrijeme koje prođe od narudžbe do primitka robe) je poznato i konstantno
- svi parametri troškova ostaju isti (tijekom beskonačnog perioda vremena)
- nedostatak zaliha može biti u cijelosti izbjegnuto ako se narudžba izvrši u pravo vrijeme.[6]

EOQ uzima u obzir tri varijable:

- troškove naručivanja
- troškove skladištenja
- ukupne godišnje troškove.

Slika 3. prikazuje odnos ranije spomenutih varijabli, što je narudžba veća, troškovi naručivanja su manji, a troškovi držanja zaliha rastu.



Slika 3. Kretanje troškova zaliha u jedinici vremena, [7]

2.3.Suvremeni modeli upravljanja zalihama

Ranije prikazani tradicionalni modeli upravljanja zalihama, kako je vidljivo temelje se na popunjavanju razine zaliha kako bi se dostigla željena količina, dok u ovim sustavima polazi se od pretpostavke da je unaprijed poznat plan proizvodnje, odnosno prodaje i da su određeni normativi utroška materijala za svaki proizvod.

U upotrebi je više suvremenih modela upravljanja koji se stalno razvijaju, unaprjeđuju te su uvedeni u tvrtke radi lakšeg, jednostavnijeg i učinkovitijeg poslovanja. S obzirom na to važno je spomenuti najvažnije i one koji su doprinijeli razvitku upravljanja zalihama i općenito logističkom poslovanju. Primjena suvremenih modela upravljanja zalihama široko otvara mogućnosti optimizacije zaliha kroz cijeli opskrbni lanac te olakšava vođenje i upravljanja unutar logističke strukture određene tvrtke. Najkorišteniji te najpoznatiji modeli upravljanja zalihama su: model planiranja materijalnih potreba (eng. Material Requirement Planning – MRP I), planiranje resursa proizvodnje (eng. Manufacturing Resource Planning – MRP II), planiranje resursa distribucije (eng. Distribution Resource Planning - DRP), planiranje resursa poduzeća (eng. Enterprise Resource Planning - ERP), napredno logističko

planiranje (eng. Advanced Planning Systems - APS) i sustav „točno na vrijeme“ (eng. Just in Time – JIT).[9]

Navedeni modeli bit će ukratko opisani u nastavku rada.

2.3.1. Planiranje materijalnih potreba – MRP

Tehnike računalne obrade podataka koje su uvedene nakon 1950. godine, omogućile su izvršavanje kompleksnih računanja i obradu velike količine podataka. U to su vrijeme razvijeni sustavi planiranja materijalnih potreba. Po prvi je puta u upravljanju zalihama uveden čimbenik vremena. Sustavi MRP rade na temelju takozvane „time-phased“, fazne potražnje i čimbenika vremena u kontroliranju zaliha. MRP sustav obuhvaća mnoge tehnike informacijskih znanosti za planiranje nabave materijala (ulaz potrebnih sirovina i dijelova) i proizvodni postupak na temelju utvrđenog proizvodnog plana za gotove proizvode. Proizvodni se plan utvrđuje na temelju tržišnih i prodajnih očekivanja. Sastav svakog proizvoda u pogledu dijelova (sirovine, sekundarni materijali i poluproizvodi) je poznat i utvrđena je sastavnica materijala.[10]

Temeljni ciljevi MRP I modela su:

- osigurati dostupnost materijala, dijelova, poluproizvoda, gotovih proizvoda za proizvodnju i isporuku kupcima
- uspostava najmanje moguće razine zaliha
- izrada plana proizvodnih aktivnosti, rasporeda isporuka i nabavnih aktivnosti.

Model počinje određivanjem količine proizvoda koje kupci potražuju i kada žele da im budu isporučeni. Potom se MRP modelom određuje vremenski plan izrade i potrebna količina pojedinih materijala i/ili dijelova potrebnih za proizvodnju određenog proizvoda.[11]

MRP I model ima prednosti i nedostatke. Njegove prednosti su:

- poboljšani poslovni rezultati
- poboljšani rezultati izvedbe proizvodnje i nadzor nad proizvodnjom kroz točnije i pravodobne informacije
- smanjenje zalihe, što vodi smanjenju zastarjelosti
- veća spremnost za isporuku u skladu s potražnjom, budući da narudžbe upravljaju proizvodnim procesom

- niži proizvodni troškovi zbog povećane učinkovitosti.[10]

Nedostaci MRP I uključuju:

- više troškove zbog češćih i manjih narudžbi, MRP I nužno ne optimizira troškove nabave materijala
- manje narudžbe povećavaju cijenu prijevoza i obično povećavaju jedinične troškove zbog izgubljenih količinskih popusta
- proizvodnja može biti usporena ili ugašena ako je isporuka spora ili ako dođe do nestašice komponenti
- računalne pakete teško je modificirati kada su jednom postavljeni
- ne uzima u obzir kapacitet postrojenja i kapacitet distribucije.[10]

2.3.2. Planiranje resursa proizvodnje – MRP II

Planiranje resursa proizvodnje predstavlja nadogradnju MRP I modela. MRP II je informacijski sustav planiranja, dizajniran tako da poboljša kontrolu nad proizvodnjom i svim vezanim funkcijama.

Zasniva se na proračunu potrebnog kapaciteta, odnosno potrebnog proizvodnog programa, MRP II sustav izračunava unatrag od datuma isporuke kako bi odredio koji je kapacitet potreban u kojoj količini i kojem trenutku u vremenu kako bi se narudžbe isporučile na vrijeme. Važno je vrlo rano znati za koji element kapaciteta u procesu (stroj, ljudi, dobavljač, itd.) postoji vjerojatnost da će postati usko grlo i kada.[10]

Koristi koje donosi MRP II ogledaju se kroz poboljšanu usluga (kraće vrijeme isporuke), manja ulaganja u zalihe (kašnjenje nabave je gotovo eliminirano, te s tim i rizik nedostataka zaliha), te veću efikasnost cjelokupnog sustava proizvodnje.[9]

2.3.3. Kanban i sustav „Just in time“

Kanban je sustav upravljanja proizvodnjom i isporukama materijala od strane korisnika. Materijali se isporučuju u fiksnim količinama (tzv. „kanban količine“) u standardnim spremnicima (posuda/kutija). Korisnici određuju kada i koliko spremnika materijala dobavljač mora isporučiti u ugovorom zadanim rokovima. Nova isporuka se inicira automatski kada

zaliha prijeđe normiranu donju granicu. Korisnici mogu dobavljača o tome obavijestiti na različite načine. Prvotno se u tu svrhu, kao nosilac informacija služila kartica (japanski kanban), pri čemu je sustav dobio i naziv. Ali to se može raditi i na način da se dobavljaču pošalje obavijest kada zaliha padne na minimalnu razinu ili pomoću ispražnjenih spremnika, koji se skupljaju na nekom centralnom mjestu u tvrtki, gdje ih dobavljač preuzima u zadanim rokovima i istodobno dovozi pune spremnike, koje je prazne, preuzeo prilikom prethodne isporuke materijala. U suvremenim se uvjetima koristi elektroničko komuniciranje. Materijale se u spremnicima identificira na temelju linijskog koda, pomoću uređaja za optičko čitanje (eng. scanner), povezanog sa računalom korisnika. Podaci o uzimanju materijala iz spremnika elektronički se izravno prenose, prema posebnom programu za potrebe Kanban sustava, u određenu datoteku dobavljača.[5]

Primjenjivost u proizvodnji koja se ponavlja, stabilnost sustava, visoka pouzdanost strojeva, standardizirani procesi i operacije, pouzdani dobavljači i velika angažiranost i stručnost radnika preduvjeti su za ispravan rad Kanban sustava. Postoje različite varijante sustava od kojih možemo izdvojiti:

- vizualni kanban (npr. svjetlosni signal prilikom praznog prostor na podu/polici)
- kanban spremnici (prazni spremnici koji putuju po sustavu ili signaliziraju da ih je potrebno nadopuniti) i
- kanban kartice (koriste se za složenije sustave s više proizvoda, svaki spremnik povezan je s jednom kanban karticom).[6]

„Just in time“ - JIT sustav razvijen je na temelju sustava Kanban. Za razliku od sustava Kanban koji je orijentiran potrošnjom, JIT sustav orijentiran je potrebama korisnika, a primjenjuje se za materijale i proizvode s velikim udjelom u vrijednosti potrošnje, za koje se isplati sinkronizirati proizvodnju u lancu stvaranja vrijednosti prema dnevnim programima rada. Geslo sinkronizirane proizvodnje glasi: Proizvodi danas ono što će sutra biti potrebno ili što će se sutra tražiti. Dnevne programe proizvodnje potrebno je precizno razraditi, kako bi se uskladili svi detalji sinkroniziranog rada, a to zahtijeva intenzivno komuniciranje između dobavljača i korisnika. JIT podrazumijeva da se na svakom stupnju proizvodnje uskladi proces rada s ostalim stupnjevima uključujući i isporuke predmeta rada, te da se proizvodnja odvija bez skladišta i s minimalnim zalihama. Da bi se JIT mogao realizirati trebaju biti ispunjene slijedeće pretpostavke:

- osigurati isporuku predmeta rada zahtijevane kakvoće (bez grešaka) kako bi se mogla eliminirati prijamna kontrola
- uskladiti kapacitete u cijelom proizvodnom lancu i osigurati visoki stupanj pouzdanosti dobavljača
- koristiti autonomne organizacijske jedinice/male tvrtke i povezati informacijske sustave kupaca i dobavljača u upravljanju zalihama
- proizvoditi u malim serijama
- suvremenim logističkim rješenjima i korištenjem sigurne prometne infrastrukture osigurati efikasan protok materijala bez zastoja (najčešće od prostorno bližih dobavljača i od manjeg broja dobavljača).[5]

2.3.4. Ostali modeli upravljanja zalihama

Model planiranja resursa distribucije – DRP kao informacijski sustav koji podržava koordinaciju unutar distribucijske mreže ima za svrhu bilježenje tokova roba i zahtjeva dostupnost informacija o tome gdje se drže zalihe, koja je roba u tranzitu i kakva su kretanja zaliha. Ovaj sustav omogućava koordinaciju odluka koje su donesene u različitim točkama distribucijske mreže. DRP sustav temelji se na načelima MRP – a.[10]

Model planiranja resursa poduzeća – ERP definira se kao softverska arhitektura koja omogućava tok informacija između svih funkcija unutar poduzeća uključujući proizvodnju, logistiku, financije i ljudske resurse. Baza podataka čitavog poduzeća, koja radi na zajedničkoj platformi, funkcionira zajedno s integriranim skupom aplikacija, konsolidirajući sve poslovne radnje u jednom računalnom okruženju. Cilj ERP sustava je da se informacija može unijeti u sustav samo jednom.[10]

ERP sustav detaljnije će biti obrađen u poglavlju „Specifičnosti upravljanja zalihama u postprodaji automobilske industrije“.

Napredno logističko planiranje, APS sustav pokriva čitav opskrbeni lanac i koristi posljednje informacije kako bi izračunao rokove kupaca koje daje. Takav sustav omogućava gotovo trenutni odgovor na zahtjeve kupaca, iako je to samo jedna od njegovih funkcija. Primjena APS sustava rezultira boljim vremenom prolaska, rokova isporuka, razine zaliha, te ukupno boljim operativnim rezultatima i višom razinom potrošačke usluge.[10]

3. MOGUĆNOSTI OPTIMIRANJA ZALIHA

U suvremenim uvjetima poslovanja, koji se sve više temelji na filozofiji „*Lean Managementa*“¹, povećava se stratezijsko značenje nabave za uspjeh poslovanja poduzeća. Strategija je važan instrument vođenja i ostvarivanja ciljeva nabave i tvrtke. Pojam „strategija“ nastao je od grčke riječi strategema što znači lukav plan, poslovno ili vojno lukavstvo kojim se nastoji ograničenim sredstvima te izborom putova i načina odvijanja aktivnosti ostvariti optimalne rezultate, koje bismo, inače, mogli ostvariti sa znatno većim sredstvima i sa znatno više rada i troškova. Poduzeće mora koristiti svoje ključne kompetencije i djelatnosti te koristiti mogućnosti dobavljača i fleksibilno ispunjavati zahtjeve tržišta. Nabava postaje organizator lanca opskrbe, uključivanja dobavljača u mrežu stvaranja vrijednosti i odgovorna je za stvaranje vrijednosti u velikom dijelu procesa reprodukcije. Te zadatke može uspješno ostvariti korištenjem instrumenata strategije nabave.[5]

Promatramo li značajke materijala i trgovačke robe, možemo utvrditi da između njih postoje vrlo velike razlike s obzirom na količine potreba, jedinične cijene, učestalost potrošnje/prodaje, rizike opskrbe i drugo. Zbog toga nije ekonomski opravdano koristiti iste postupke i sustave nabavljanja te upravljanja zalihama za sve materijale i trgovačku robu. S obzirom da se posluje s nekoliko tisuća ili, ponekad, i desetaka tisuća vrsta materijala treba ih razvrstati u specifične skupine primjenjujući odgovarajuće analize. Na taj način se razvrstavanjem pojednostavljuje, odnosno racionalizira proces poslovanja.[5]

Analize koje omogućuju optimiranje zaliha bit će objašnjenje u daljnjim poglavljima, a one su ABC i XYZ analiza, te njihova kombinacija, te Multi – Echelon optimizacija.

3.1. ABC analiza


Prvi korak u upravljanju zalihama svake tvrtke je korištenje metode nazvane ABC analiza. ABC analiza (eng. ABC analysis) je analitička metoda širokog opsega primjene u

¹ „Vitka organizacija“ (eng. *Lean Management*) je oblik organizacije koji se razvio potkraj dvadesetog stoljeća. Filozofija vitke organizacije bi se mogla izraziti kao težnja da se preko integriranja već postojećih koncepata i inovacija ostvare „skokovita“ poboljšanja. Vitka organizacija omogućuje održavanje proizvodnje s manje osoblja, proizvodnih površina i investicija, te manje ulaganja u istraživanje i razvoj. Vitke organizacije su u stanju proizvoditi veći broj varijanti proizvoda uz visok stupanj kakvoće. one su organizacije koje prolaze kroz kontinuirani proces poboljšanja, a timski rad je temelj njihovog oblikovanja. Najbolji primjer takvih organizacija je autoindustrija.[12]

robnom i materijalnom poslovanju. Temelji se na saznanjima do kojih je došao talijanski ekonomist i sociolog iz 19. stoljeća Vilfredo Pareto. Svrha ove metode je uspoređivanje djelotvornog sustava kontrole i upravljanja predmetima iz okvira nabavnog, prodajnog i skladišnog poslovanja provođenjem različitih postupaka radi postizanja što veće ekonomičnosti i povećanja uspješnosti poslovanja. Cilj metode je bolja kontrola nad svakim segmentom poslovanja, bila to prodaja, nabava, troškovi, odnosi s kupcima ili dobavljačima te uočavanje uzroka problema i pronalaženje načina njihovog rješavanja.[5]

ABC analiza u literaturi je poznata i pod nazivom „Paretova analiza“. Pareto je istraživao koje aktivnosti u kompleksnim zadacima daju najbolje rezultate. Utvrdio je da 80% uspjeha proizlazi od samo 20% aktivnosti. Ta se spoznaja mogla prenijeti na mnoga područja ljudskog rada pa je tako uvjetima industrijske proizvodnje u SAD – u razvijena ABC analiza, kako bi se odredio redoslijed ekonomskog značenja pojedinih materijala s ciljem njihova razvrstavanja u tri vrijednosne skupine (A, B i C) prema udjelu u ukupnoj vrijednosti potrošnje/zaliha materijala. ABC analiza treba omogućiti razlikovanje bitnog od nebitnog, s ciljem da se u nabavi stvore strategijske smjernice racionalizacije poslovanja s materijalima koncentracijom aktivnosti na područje koje ima veliko ekonomsko značenje.[5]

Slika 4. prikazuje klasičan Pareto dijagram iz kojeg možemo zaključiti ako ga primijenimo na poslovne aktivnosti da 80% godišnje prodaje, odnosno 80% vrijednosti proizlazi iz 20% artikala, dok ostalih 20% prodaje pokriva 80% artikala.



Slika 4. Klasičan Pareto dijagram, [7]

Postupak provedbe ABC analize odvija se u tri faze:

- obuhvat podataka o godišnjim potrebama ili potrošnji materijala u zadnjih 12 mjeseci prema vrstama i izračunavanje vrijednosti potreba/potrošnje množenjem količina pojedinih materijala s njihovim planskim ili prosječnim nabavnim cijenama
- sortiranje materijala u pripadajućem slijedu prema vrijednosti godišnjih potreba/potrošnje te izračunavanje postotnog udjela vrijednosti pojedinog materijala u ukupnoj vrijednosti godišnjih potreba/potrošnje i kumuliranje postotnih udjela
- usporedba kumulativnih postotnih udjela vrijednosti godišnje potrebe/potrošnje i postotnog udjela broja vrsta, na temelju čega možemo odrediti skupine A, B i C te za svaki materijal kojoj skupini pripada.[5]

Rezultati ABC analize značajni su za različita područja poslovanja nabave. S obzirom da se temelje na podacima iz prošlosti, a tijekom vremena mogu se promijeniti i cijene i količine potrošnje pojedinih materijala, potrebno je učestalo provoditi klasifikaciju. Budući da materijali iz skupine A nose većinu vrijednosti, preporučuje se tjedno preispitivanje politike njihovih zaliha, mjesečno je poželjno ispitivati politiku zaliha materijala skupine B. Konačno, ovisno o vrijednosti materijala, tvrtka se može odlučiti za držanje zalihe materijala iz skupine C (ako je riječ o velikoj količini materijala vrlo niske cijene) ili pak ne držanje zalihe (ako je riječ o maloj potražnji vrlo skupih proizvoda). Materijale nije nužno uvijek podijeliti u tri skupine. Ako između vrijednosti godišnjih potreba/potrošnje materijala postoje malene razlike, tada se mogu koristiti samo dvije skupne (A i B), a ako su razlike velike može se napraviti i četiri (A, B, C i D) ili pet skupina materijala, s kojima se različito postupa, kako bi se racionalizirali postupci nabavljanja i upravljanja zalihama.[5]

3.2. XYZ analiza


U prethodnom poglavlju objašnjena je ABC analiza koja se temelji na kriteriju razvrstavanja zaliha prema njihovoj vrijednosti. S obzirom da takvo razvrstavanje ne daje uvijek zadovoljavajuće rezultate, tvrtke su primorane koristiti i druge metode pri optimiranju svojih zaliha, zasnovane na različitim kriterijima.

Druga metoda korištena pri optimiranju zaliha je XYZ analiza (eng. XYZ analysis) koja koristi kriterij kontinuiteta potrošnje/prodaje materijala, zasnovan na povijesnim podacima, te kriteriju sigurnosti prognoze potrošnje.

XYZ analiza materijale klasificira također u tri skupine:

- U skupinu X ulaze materijali koji se kontinuirano troše ili se u njihovoj potrošnji javljaju manja kolebanja (do 10%) pa se postiže velika točnost prognoze potrošnje. Njihova prodaja ne mijenja se značajno tijekom vremena (može varirati samo neznatno) tako da se prognoza buduće potražnje može odrediti s velikom točnošću (idealni primjer za X artikle je sprej VD 40). Preporuka za X artikle je da ih uvijek ima u onoj količini koliko je potrebno dok ne stigne slijedeća isporuka (nije potrebno predvidjeti veliku sigurnosnu zalihu).
- U skupinu Y ulaze materijali koji se troše diskontinuirano, njihova potrošnja nije niti stalna niti povremena. Kolebanja potrošnje u pojedinim vremenskim razdobljima (npr. u pojedinim mjesecima tijekom godine) su do 60%. Kod Y artikala mogu se pratiti trendovi (npr. da se upotreba poveća ili smanjuje kroz neko vrijeme ili da je karakteristična sezonalnost potražnje). Zbog toga je moguće postići samo srednju točnost prognoze.
- U skupinu Z artikala ulaze materijali koji se povremeno troše uz velike odklone u količini potrošnje (preko 60%, potražnja jako varira i sporadična je, dok u pojedinim vremenskim razdobljima uopće je niti nema) pa se gotovo ne može spoznati trend potrošnje. Za takve se materijale postiže mala točnost prognoze koja je vrlo zahtjevna, te je preporuka da se u prognoziranje uloži više vremena, uz ručno računanje bez automatizacije.[7]

Istraživanja u praksi su pokazala da u skupinu X ulazi oko 50% vrsta materijala, u skupinu Y oko 20%, a u skupinu Z oko 30% od ukupnog broja vrsta materijala. Za skupinu materijala X preporučljiva je opskrba sa vlastitih zaliha, dok je za materijale skupine Z ekonomičnija pojedinačna opskrba.[5]



Slika 5. Grafički prikaz XYZ analize, [7]

U postupku provedbe XYZ analize na temelju obuhvata podataka o godišnjim potrebama ili potrošnji materijala u određenom vremenskom periodu prema vrstama potrebno je odrediti standardnu devijaciju potražnje po artiklu. Koeficijent varijacije po artiklu (koji je količnik standardne devijacije i prosječne potražnje) te dobivene podatke sortirati od najmanjeg do najvećeg prema koeficijentu varijacije.[6]

3.3. Primjena kombinacije ABC i XYZ analize

Nakon što su u prethodnim poglavljima objašnjenje glavne karakteristike ABC i XYZ analize, možemo zaključiti da primjena svake analize zasebno ima odgovarajuće nedostatke. Kako bismo poboljšali interpretaciju analize materijala, potrebno je rezultate dobivene ABC i XYZ analizom međusobno kombinirati, odnosno provesti unakrsnu ABC/XYZ analizu.

Kombinacijom rezultata ABC i XYZ analize dobiva se matrica s devet različitih skupina materijala za koje se dobiju dodatni uvidi i mogućnosti djelovanja na određene skupine artikala, te za koje možemo odrediti specifične strategije nabavljanja i dispozicije materijala.[5]

Matrični prikaz pojedinih skupina prikazan je Tablicom 1.

Tablica 1. Matrični prikaz kombinacije rezultata ABC i XYZ analize

	Skupna X	Skupna Y	Skupina Z
Skupina A	Velik udio u ukupnoj vrijednosti. Kontinuirana potrošnja. Velika točnost prognoze potreba.	Velik udio u ukupnoj vrijednosti. Diskontinuirana potrošnja. Srednja točnost prognoze potreba.	Veliki udio u ukupnoj vrijednosti. Povremena potrošnja. Malena točnost prognoze potreba.
Skupna B	Srednji udio vrijednosti potrošnje. Kontinuirana potrošnja. Velika točnost prognoze potreba.	Srednji udio u vrijednosti. Diskontinuirana potrošnja. Srednja točnost prognoze potreba.	Srednji udio u vrijednosti. Povremena potrošnja. Malena točnost prognoze potreba.
Skupna C	Maleni udio u vrijednosti. Kontinuirana potrošnja. Velika točnost prognoze potreba.	Maleni udio u vrijednosti. Diskontinuirana potrošnja. Srednja točnost prognoze potreba.	Maleni udio u ukupnoj vrijednosti. Povremena potrošnja. Malena točnost prognoze potreba.

Izvor: [5]

Skupinama AX, AY i BX treba pokloniti veliku pozornost kako bi se postigle što povoljnije nabavne cijene i opskrba uz što manje zalihe. Za te skupne preporučljivo je sekundarne potrebe određivati deterministički, sinkronizirati proizvodnju s dobavljačima i ugovoriti JIT sustav nabavljanja. Skupinama AZ, BY i CX treba pokloniti u nabavi i dispoziciji materijala normalnu (srednju) pozornost i organizirati pojedinačnu opskrbu prema potrebama korisnika, dok se skupinama BZ, CY i CZ pridodaje malena pozornost, potrebe se utvrđuju stohastički, opskrba se regulira sa vlastitih zaliha, ponekad se nabavlja u količinama za jednogodišnje potrebe ili se opskrba prepušta dobavljaču.[5]

4. SPECIFIČNOSTI UPRAVLJANJA ZALIHAMA POSTPRODAJE AUTOMOBILSKE INDUSTRIJE

Prodaja automobila je nezavisna potražnja određena tržištem. Nije moguće procijeniti koliko osobnih vozila će prodajno mjesto prodati tijekom godine dana. O prodaji automobila ovisi i potražnja za njihovim rezervnim dijelovima. Zalihe rezervnih dijelova predstavljaju velik izazov za osobe koje se bave upravljanjem istih. Tvrtke koje se bave njihovom prodajom broje poprilično velik broj artikala koje treba optimizirati. Kod upravljanja zalihama osnovni problem je neizvjesnost potražnje kupaca, što donosi poteškoće u njihovom cjelokupnom upravljanju.

Tvrtke imaju ograničene resurse na raspolaganju, stoga moraju održavati zalihe na optimalnoj razini kako bi ostale konkurentne na tržištu. Jedinični trošak dijelova automobila je visok, a prekomjerna zaliha može imati ozbiljan utjecaj na kapital. S druge strane, posjedovati u stvarnom vremenu određenu količinu zaliha ključni je preduvjet za udovoljavanje nestabilnim zahtjevima kupaca. Tvrtke moraju brzo reagirati na promjene na tržištu kako bi zadovoljile zahtjeve kupaca. To znači da moraju zadovoljavati razine zaliha za popunjavanje narudžbi, jer povratni nalozi i kašnjenja mogu dovesti do izgubljenih prodajnih mogućnosti i štetiti ugledu tvrtke.[17]

Prilikom planiranja nabave rezervnih dijelova, potrebno je provesti klasifikaciju dijelova i kategorizirati ih prema učestalosti potrošnje. Rezervni dijelovi su sastavni dio kratkotrajne materijalne imovine bez obzira na pojedinačnu nabavnu vrijednost, oni se ugrađuju u automobile radi popravka odnosno održavanja.[1]

Upravljanje zalihama u postprodaji automobilske industrije obuhvaća:

- predviđanje potreba za pojedinim automotivima
- definiranje potrebnog asortimana
- definiranje kriterija za popunu skladišta
- definiranje cijena automotiva
- praćenje stanja zaliha u skladištu.[13]

Osnovno pitanje koje se postavlja je koje zalihe držati na stanju i u kojoj količini da bi se zadovoljila visoka razina usluge kupcima, postigla tražena optimizacija zaliha i time povećao

profit. Uspješnost njihovog upravljanja temelji se na ranije spomenutim provedbama analiza (ABC i XYZ), te na kvalitetnom informacijskom sustavu.

Kao vodeći sustav u automobilske postprodaji koristi se sustav ERP njegova uloga i značaj bit će analizirani u daljnjem poglavlju.

4.1. Primjena ERP sustava pri optimizaciji zaliha

Na konkurentskom globalnom tržištu jedan od najučinkovitijih načina postizanja konkurentске prednosti je sposobnost ubrzavanja procesa dobavljačkog lanca pomoću ERP sustava. „Integralni poslovni informacijski sustav“ (eng. Enterprise resources planning system - ERP) je vrsta poslovnog računalnog programa koji integrira različite upravljačke i informacijske sustave unutar neke tvrtke, omogućuje planiranje nabavnih, financijskih i svih drugih resursa pa informacije za operativno poslovanje i poslovno odlučivanje stvara dostupnima u tzv. realnom vremenu. To je rješenje informacijskog sustava širom tvrtke, baza podataka čitave tvrtke, koja radi na zajedničkoj platformi, funkcionira zajedno s integriranim skupom aplikacija, konsolidirajući sve poslovne radnje u jednom računalnom okruženju. Cilj ERP sustava je da se informacija može unijeti u računalni sustav samo jednom. Na primjer, predstavnik prodaje unese narudžbu u ERP sustav tvrtke, kad tvornica počne slagati narudžbu, odjel isporuka može do tada provjeriti programe i procijeniti očekivani datum prijevoza. Skladište provjerava može li se narudžba popuniti iz zaliha i zatim obavijestiti proizvodnju o potrebnoj količini robe. Kada se narudžba realizira, informacija ide direktno u izvještaj o prodaji na znanje upravi.[10]

ERP prvenstveno nudi mogućnost prilagodbe i uporabe gotovih programskih rješenja odnosno, na taj način, programsku podršku kreiranu po mjeri određenog korisnika. Takvi se programski paketi mogu prilagoditi potrebama konkretne organizacije i postojećem informacijskom sustavu dotične organizacije. Prilagodba ERP modela konkretnom korisniku obavlja se posebnim alatima ili standardnim programskim jezicima. Sam posao prilagodbe i uvođenja, ključan je faktor za uspješnu instalaciju i uvođenje ERP sustava. Bitno je napomenuti da u današnje vrijeme većina ERP sustava je raspoloživa u modularnom obliku, što proizvodnim, a i drugim organizacijama ostavlja mogućnost da sustav „kroje“ po vlastitoj mjeri i prema svojim potrebama i mogućnostima.[15]

Svojstva ERP sustava su obično podijeljena u module i variraju ovisno o proizvođaču, a bilo bi poželjno da su slijedeća:

- Planiranje poslovanja – modul koji osigurava računalnu potporu u procesu kapitalnog investiranja, u procesu ulaganja i omogućava nadzor i upravljanje internim troškovima i vanjskim akvizicijama.
- Kontrolni modul – prije svega usmjeren je na integriranje financijskih i podataka vezanih uz menadžersko računovodstvo.
- Financijski i računovodstveni model – treba osigurati integriranu Glavnu knjigu, uključujući i integriranje Salda – konta.
- Modul nabave – treba osigurati potpuno integriranje proizvodne organizacije s njenim dobavljačima kako bi se osigurao vremenski što precizniji zahtjev za isporukom sirovina, materijala za održavanje i drugo. Poželjno je i da modul sadržava mogućnost elektroničke prodaje kako bi se automatiziralo naručivanje i plaćanje prema dobavljačima, što može značajno utjecati na smanjenje zaliha.
- Proizvodni modul – treba uključivati mogućnost specifičnih zahtijeva prodavača, distributera i kupaca. Ovaj modul podrazumijeva integriranje cjenovne politike, kreditiranja, sustava provizija, načina osiguranja naplate i slično.[15]

Čimbenici koji utječu na uspješno uvođenje ERP sustava su:

- pravilno odabrana strategija implementacije
- za implementaciju ERP sustava potrebno je mijenjati poslovne procese kao i način rada i navike dosadašnjeg obavljanja istih
- povećanjem obujma prilagodbe ERP sustava i mijenjanjem standardnih rješenja, povećavaju se troškovi implementacije
- ocjena i povrat ulaganja u ERP sustave preduvjet je ulaganja u projekt implementacije ERP sustava.[15]

4.2.Prednosti i nedostaci ERP sustava

Prednosti ERP sustava očituju se u:

- bržem obrtaju proizvodne imovine, procesi kao što su planiranje proizvodnje i nabave automatizirani su, pa se deseterostruko povećava proizvodna zaliha, a ujedno se smanjuju troškovi skladištenja od 10% do 40%

- poboljšanje usluga kupcu, odnosno povećanje ispunjenja narudžbi od 80% do 90%, što rezultira zadovoljstvom kupca i njihovim zadržavanjem
- veća preciznost inventara
- povećanje produktivnosti, uštede u vremenu, ERP sustav može skratiti vrijeme proizvodnje grupiranjem sličnih poslova i osiguranjem koordinacije ljudi, alata i strojeva
- pravovremena naplata, ERP sustav automatski generira listu zakašnjelih plaćanja kupaca (kupci se obavještavaju putem opomena ili im se do podmirenja dugovanja blokira isporuka robe).[15]

Uz navedene treba još spomenuti i ostale, jednako važne prednosti ERP sustava kao što su poboljšanje i standardizacija poslovnih procesa, pristup informacijama u realnom vremenu, povećanje fleksibilnosti, smanjenje troškova održavanja, optimizacija lanca opskrbe, povećanje prodaje i profita, razvoj poslovanja, smanjenje vremena od narudžbe do isporuke, smanjenje operativnih troškova te povećanje kontrole proizvoda.[15]

Nedostaci ERP sustava su:

- implementacija ERP sustava je dugotrajan i skup posao
- javlja se velika potreba za konzultantima zbog zahtjeva za velikom prilagodbom ERP sustava
- potreba za reorganizacijom poslovnih procesa kako bi se samo poslovanje prilagodilo sustavu.[15]

5. OPTIMIRANJE ZALIHA STUDIJA SLUČAJA

Studija slučaja optimiranja zaliha napravljena je prema stvarnim podacima tvrtke Inter Cars Hrvatska d.o.o., podružnice europskog distributera rezervnih dijelova, guma, akumulatora i ostale opreme za osobna i teretna vozila, te motocikle. Misija tvrtke je osigurati najkvalitetniju uslugu distribucije rezervnih dijelova za sve vrste vozila, kako bi to postigla pri optimiranju svojih zaliha koristi suvremeni informacijski sustav Microsoft Dynamics NAV, jednog od vodećih informacijskih ERP sustava za upravljanje poslovanjem tvrtke te posebno prilagođenog tržištu i zakonskim propisima Republike Hrvatske. Podržava poslovne procese od financija, marketinga i prodaje do proizvodnje, nabave, distribucije i skladištenja.[16]

U svrhu izrade ovog rada tvrtka Inter Cars Hrvatska d.o.o. ustupila je podatke o polugodišnjoj prodaji 42 artikla različitih kategorija, s njihovim šiframa i cijenama, prikazanih tablicom 2., gdje Int. No. (eng. Internal Number) označava šifru pod kojom se artikl vodi u tvrtki, a JC jediničnu cijenu pojedinog artikla. Nad podacima će se provesti unakrsna ABC/XYZ analiza, pomoću programskog alata Microsoft Excel, kako bi mogli odrediti najbolje strategije nabavljanja, te minimizirati troškove držanja nepotrebnih zaliha.

U daljnjem tekstu bit će opisan postupak provedbe ABC/XYZ analize.

Tablica 2. Polugodišnja prodaja 42 artikla, sa njihovom jediničnom cijenom

Int. No.	Siječanj	Veljača	Ožujak	Travan	Svibanj	Lipanj	JC
D033F9	1.846	488	424	391	461	493	66,8
D14532	541	269	417	269	302	229	86,6
D033F7	823	231	244	212	231	253	52,9
D24145	608	167	184	153	211	247	59,4
C6596B	462	731	786	913	845	1.226	13,6
D65CA6	255	237	272	305	326	250	38,2
B8EBA5	0	0	229	289	350	339	43,2
D65CAD	394	418	484	478	540	421	10,4
A7FA71	2.511	958	663	434	660	524	5,0
ADE016	615	605	738	696	792	667	5,4
9DC8BD	279	272	334	326	368	329	10,6
A89010	970	2.388	1.353	1.387	972	817	2,2
ADDFDB	505	487	595	519	556	583	4,7
421657	331	408	540	402	418	444	5,9
A8EA2E	231	231	293	237	219	194	10,1
ADE01F	480	444	661	545	665	535	3,9
9F0420	223	371	339	477	582	421	4,7
410889	514	457	391	330	367	370	4,7
B68D93	211	190	232	230	229	182	8,6
290344	881	155	46	58	47	29	9,4
ADDFD8	283	299	352	327	364	414	5,1
9DF2A2	221	341	247	314	297	262	5,2
396391	813	559	777	613	716	647	2,2
ADE00A	306	362	387	286	392	297	4,2
259532	238	192	326	236	247	216	5,7
B44660	204	252	244	242	255	348	5,3
ADDFDA	167	153	221	207	203	229	6,3
ADDFE3	235	206	241	248	265	227	5,3
9DF2A3	252	370	535	444	386	389	2,6
9B3C88	187	188	228	191	199	171	5,7
9F041D	115	713	183	177	1.448	736	2,1
B49C2A	288	358	525	280	379	272	3,1
396392	224	232	204	181	197	197	4,0
B3CD80	66	193	57	848	117	701	2,5
396389	221	192	211	189	225	224	3,6
D63356	163	182	545	216	255	251	2,9
316625	365	264	315	236	258	204	2,5
257284	221	196	246	197	216	219	2,9
DD81EA	0	0	325	350	325	0	2,6
472269	583	354	360	428	431	364	0,4
A96FD9	134	404	189	290	280	175	0,4
279886	707	783	963	902	780	785	0,1

Izvor: [18]

5.1.Provedba ABC analize

Analizu prvotno započinjemo provedbom ABC analize. Prvi korak u određivanju grupa (A, B ili C) artikala je izračunati ukupnu prodaju u danom razdoblju za pojedini artikl. Ukupna prodaja po artiklu, u Tablici 3. označena kao UP te je jednaka zbroju prodaje artikla u šest mjeseci pomnoženog s jediničnom cijenom artikla (JC).[6]

Na primjer:

$$UP_{D033F9} = Siječanj_{D033F9} + \dots + Lipanj_{D033F9} * JC_{D033F9} \quad (2)$$

$$UP_{D033F9} = (1846 + 488 + 424 + 391 + 461 + 493) * 66.8 \quad (2)$$

$$UP_{D033F9} = 274\,027,4 \quad (2)$$

Nakon izračuna UP potrebno je izračunati udio u ukupnoj prodaji pojedinog artikala – UUP. UUP izračunavamo na način da podijelimo UP sa ukupnom zaradom u danom periodu, koja je jednaka zbroju UP – ova svih artikala.[6]

Na primjer:

$$UUP_{D033F9} = \frac{UP_{D033F9}}{Ukupna\ zarada} \quad (3)$$

$$UUP_{D033F9} = \frac{274\,027,4}{1\,177\,037,218} \quad (3)$$

$$UUP_{D033F9} = 0,2328 = 23,28 \% \quad (3)$$

Ukupna zarada za izračun koristi funkciju SUM programskog alata Microsoft Excela. Izračun je prikazan Slikom 6.

I44 fx =SUM(I2:I43)									
	A	B	C	D	E	F	G	H	I
10	A7FA71	2.511	958	663	434	660	524	5,0	28827,7
11	ADE016	615	605	738	696	792	667	5,4	22294,1
12	9DC8B0	279	272	334	326	368	329	10,6	20308,2
13	A89010	970	2.388	1.353	1.387	972	817	2,2	17492,7
14	ADD0DB	505	487	595	519	556	583	2,2	15169,2
15	421657	331	408	540	402	418	444	5,9	15093,3
16	A8EA2E	231	231	293	237	219	194	10,1	14212,8
17	ADE01F	480	444	661	545	665	535	3,9	12946,8
18	9F0420	223	371	339	477	582	421	4,7	11257,9
19	410889	514	457	391	330	367	370	4,7	11481,4
20	B68D93	211	190	232	230	229	182	8,6	11002,1
21	290344	881	155	46	58	47	29	9,4	11435,4
22	ADD0D8	283	299	352	327	364	414	5,1	10355,4
23	9DF2A2	221	341	247	314	297	262	5,2	8694,9
24	396391	813	559	777	613	716	647	2,2	8983,8
25	ADE00A	306	362	387	286	392	297	4,2	8495,3
26	259532	238	192	326	236	247	216	5,7	8344,6
27	B44660	204	252	244	242	255	348	5,3	8238,4
28	ADD0DA	167	153	221	207	203	229	6,3	7383,7
29	ADD0E3	235	206	241	248	265	227	5,3	7472,2
30	9DF2A3	252	370	535	444	386	389	2,6	6095,3
31	9B3C88	187	188	228	191	199	171	5,7	6658,7
32	9F041D	115	713	183	177	1.448	736	2,1	7068,2
33	B49C2A	288	358	525	280	379	272	3,1	6454,0
34	396392	224	232	204	181	197	197	4,0	4960,0
35	B3CD80	66	193	57	848	117	701	2,5	4956,3
36	396389	221	192	211	189	225	224	3,6	4540,0
37	D63356	163	182	545	216	255	251	2,9	4743,3
38	316625	365	264	315	236	258	204	2,5	4089,8
39	257284	221	196	246	197	216	219	2,9	3809,8
40	D081EA	0	0	325	350	325	0	2,6	2625,0
41	472269	583	354	360	428	431	364	0,4	1004,8
42	A96FD9	134	404	189	290	280	175	0,4	601,1
43	279886	707	783	963	902	780	785	0,1	562,6
44								Ukupna zarada=	1177037,218
45									

Slika 6. Izračun ukupne zarade u Microsoft Excelu

Izvor: [18]

Dobiveni udjeli u ukupnoj prodaji sortiraju se od najvećeg prema najmanjem, zbrajaju se na način prikazan Slikom 7. kako bi se dobila kumulativna vrijednost, označena u Tablici 3. kao – KUM. Kumulativna vrijednost pojedinog artikla označava pripadnost pojedinoj grupi artikala.[6]

fx =K2+J3								
C	D	E	F	G	H	I	J	K
Veljača	Ožujak	Travan	Svibanj	Lipanj	JC	UP	UUP	KUM
488	424	391	461	493	66,8	274027,4	23,28%	23,28%
269	417	269	302	229	86,6	175512,5	14,91%	38,19%
231	244	212	231	253	52,9	105448,4	8,96%	47,15%
167	184	153	211	247	59,4	93259,8	7,92%	55,07%
731	786	913	845	1.226	13,6	67737,4	5,75%	60,83%
237	272	305	326	250	38,2	62822,0	5,34%	66,17%
0	229	289	350	339	43,2	52138,1	4,43%	70,60%
418	484	478	540	421	10,4	28432,5	2,42%	73,01%
958	663	434	660	524	5,0	28827,7	2,45%	75,46%
605	738	696	792	667	5,4	22294,1	1,89%	77,36%
272	334	326	368	329	10,6	20308,2	1,73%	79,08%

Slika 7. Izračun kumulativne vrijednosti u Microsoft Excelu.

Izvor: [18]

Tablicom 3. prikazane se vrijednosti pojedinog izračuna te pripadnost artikala pojedinoj grupi. Temeljem ABC analize utvrđeno je da artikli čija je kumulativna vrijednost manja ili jednaka 70% pripadaju skupini A, artikli kumulativne vrijednosti od 70% do 90% pripadaju skupini B, a ostali skupini C. Od ukupno 42 artikla šest ih pripada grupi A, 14 grupi B, a ostala 22 artikla pripada grupi C.

Tablica 3. Kategorizacija 42 artikla prema ABC analizi.

Int. No.	Siječanj	Veljača	Ožujak	Travanj	Svibanj	Lipanj	JC	UP	UUP	KUM	ABC
D033F9	1.846	488	424	391	461	493	66,8	274027,4	23,28%	23,28%	A
D14532	541	269	417	269	302	229	86,6	175512,5	14,91%	38,19%	A
D033F7	823	231	244	212	231	253	52,9	105448,4	8,96%	47,15%	A
D24145	608	167	184	153	211	247	59,4	93259,8	7,92%	55,07%	A
C6596B	462	731	786	913	845	1.226	13,6	67737,4	5,75%	60,83%	A
D65CA6	255	237	272	305	326	250	38,2	62822,0	5,34%	66,17%	A
B8EBA5	0	0	229	289	350	339	43,2	52138,1	4,43%	70,60%	B
D65CAD	394	418	484	478	540	421	10,4	28432,5	2,42%	73,01%	B
A7FA71	2.511	958	663	434	660	524	5,0	28827,7	2,45%	75,46%	B
ADE016	615	605	738	696	792	667	5,4	22294,1	1,89%	77,36%	B
9DC8BD	279	272	334	326	368	329	10,6	20308,2	1,73%	79,08%	B
A89010	970	2.388	1.353	1.387	972	817	2,2	17492,7	1,49%	80,57%	B
ADDFDB	505	487	595	519	556	583	4,7	15169,2	1,29%	81,86%	B
421657	331	408	540	402	418	444	5,9	15093,3	1,28%	83,14%	B
A8EA2E	231	231	293	237	219	194	10,1	14212,8	1,21%	84,35%	B
ADE01F	480	444	661	545	665	535	3,9	12946,8	1,10%	85,45%	B
9F0420	223	371	339	477	582	421	4,7	11257,9	0,96%	86,40%	B
410889	514	457	391	330	367	370	4,7	11481,4	0,98%	87,38%	B
B68D93	211	190	232	230	229	182	8,6	11002,1	0,93%	88,31%	B
290344	881	155	46	58	47	29	9,4	11435,4	0,97%	89,28%	B
ADDFD8	283	299	352	327	364	414	5,1	10355,4	0,88%	90,16%	C
9DF2A2	221	341	247	314	297	262	5,2	8694,9	0,74%	90,90%	C
396391	813	559	777	613	716	647	2,2	8983,8	0,76%	91,67%	C
ADE00A	306	362	387	286	392	297	4,2	8495,3	0,72%	92,39%	C
259532	238	192	326	236	247	216	5,7	8344,6	0,71%	93,10%	C
B44660	204	252	244	242	255	348	5,3	8238,4	0,70%	93,80%	C
ADDFDA	167	153	221	207	203	229	6,3	7383,7	0,63%	94,42%	C
ADDFE3	235	206	241	248	265	227	5,3	7472,2	0,63%	95,06%	C
9DF2A3	252	370	535	444	386	389	2,6	6095,3	0,52%	95,58%	C
9B3C88	187	188	228	191	199	171	5,7	6658,7	0,57%	96,14%	C
9F041D	115	713	183	177	1.448	736	2,1	7068,2	0,60%	96,74%	C
B49C2A	288	358	525	280	379	272	3,1	6454,0	0,55%	97,29%	C
396392	224	232	204	181	197	197	4,0	4960,0	0,42%	97,71%	C
B3CD80	66	193	57	848	117	701	2,5	4956,3	0,42%	98,13%	C
396389	221	192	211	189	225	224	3,6	4540,0	0,39%	98,52%	C
D63356	163	182	545	216	255	251	2,9	4743,3	0,40%	98,92%	C
316625	365	264	315	236	258	204	2,5	4089,8	0,35%	99,27%	C
257284	221	196	246	197	216	219	2,9	3809,8	0,32%	99,59%	C
DD81EA	0	0	325	350	325	0	2,6	2625,0	0,22%	99,82%	C
472269	583	354	360	428	431	364	0,4	1004,8	0,09%	99,90%	C
A96FD9	134	404	189	290	280	175	0,4	601,1	0,05%	99,95%	C
279886	707	783	963	902	780	785	0,1	562,6	0,05%	100,00%	C
Ukupna zarada =			1177037,218								

Izvor: [18]

5.2.Provedba XYZ analize

Klasifikacija artikala XYZ analizom temelji se na koeficijentu varijacije označenom u Tablici 4. kraticom CV. Ako je CV manji od 10 % artikli se svrstavaju u grupu X, ako je CV u rasponu od 10 % do 25 % artikli pripadaju grupi Y, a ostali artikli svrstavaju se u grupu Z.

Koeficijent varijacije predstavlja omjer između standardne devijacije (u tablici 4. označene kraticom – SD) i prosječne potražnje po artiklu (PP).[6]

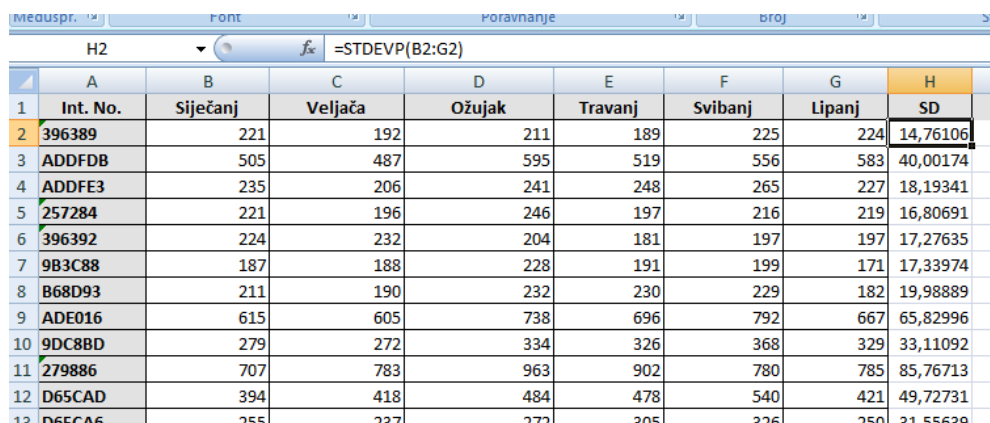
Na primjer:

$$CV_{396389} = \frac{SD_{396389}}{PP_{396389}} \quad (4)$$

$$CV_{396389} = \frac{14,76106}{210} \quad (4)$$

$$CV = 0,0702 = 7,02 \% \quad (4)$$

Standardna devijacija i prosječna potražnja po artiklu izračunate su uz pomoć programskog alata Microsoft Excela, funkcijom STDEVP kako je prikazano na Slici 8. za SD,



	A	B	C	D	E	F	G	H
	Int. No.	Siječanj	Veljača	Ožujak	Travanj	Svibanj	Lipanj	SD
2	396389	221	192	211	189	225	224	14,76106
3	ADDFDB	505	487	595	519	556	583	40,00174
4	ADDFE3	235	206	241	248	265	227	18,19341
5	257284	221	196	246	197	216	219	16,80691
6	396392	224	232	204	181	197	197	17,27635
7	9B3C88	187	188	228	191	199	171	17,33974
8	B68D93	211	190	232	230	229	182	19,98889
9	ADE016	615	605	738	696	792	667	65,82996
10	9DC8BD	279	272	334	326	368	329	33,11092
11	279886	707	783	963	902	780	785	85,76713
12	D65CAD	394	418	484	478	540	421	49,72731
13	D65CAD	255	237	277	305	326	250	31,55639

Slika 8. Izračun standardne devijacije u Microsoft Excelu

Izvor: [18]

i funkcijom AVERAGE (Slika 9.) za izračun PP.

I2 fx =AVERAGE(B2:G2)									
	A	B	C	D	E	F	G	H	I
1	Int. No.	Siječanj	Veljača	Ožujak	Travanj	Svibanj	Lipanj	SD	PP
2	396389	221	192	211	189	225	224	14,76106	210
3	ADDFDB	505	487	595	519	556	583	40,00174	541
4	ADDFE3	235	206	241	248	265	227	18,19341	237
5	257284	221	196	246	197	216	219	16,80691	216
6	396392	224	232	204	181	197	197	17,27635	206
7	9B3C88	187	188	228	191	199	171	17,33974	194
8	B68D93	211	190	232	230	229	182	19,98889	212
9	ADE016	615	605	738	696	792	667	65,82996	686
10	9DC8BD	279	272	334	326	368	329	33,11092	318
11	279886	707	783	963	902	780	785	85,76713	820
12	D65CAD	394	418	484	478	540	421	49,72731	456
13	D65CAD	394	418	484	478	540	421	49,72731	456

Slika 9. Izračun prosječne potražnje po artiklu u Microsoft Excelu

Izvor: [18]

Nakon izračuna artikle je potrebno sortirati temeljem vrijednosti koeficijenta varijacije od najmanjeg do najvećeg i prema prethodnim uputama razvrstati u grupe X, Y ili Z.

Tablicom 4. prikazana je XYZ analiza artikala. U tablici je izračunat koeficijent varijacije za svaki pojedini artikl, kojim kako je ranije spomenuto određujemo pripadnost artikla pojedinoj grupi. Iz tablice možemo očitati kako osam artikala pripada grupi X, 18 grupi Y i 16 artikala grupi Z.

Tablica 4. Kategorizacija 42 artikla prema XYZ analizi.

Int. No.	Siječanj	Veljača	Ožujak	Travan	Svibanj	Lipanj	SD	PP	CV	XYZ
396389	221	192	211	189	225	224	14,76106	210	7,02%	X
ADDFDB	505	487	595	519	556	583	40,00174	541	7,40%	X
ADDFE3	235	206	241	248	265	227	18,19341	237	7,68%	X
257284	221	196	246	197	216	219	16,80691	216	7,79%	X
396392	224	232	204	181	197	197	17,27635	206	8,39%	X
9B3C88	187	188	228	191	199	171	17,33974	194	8,94%	X
B68D93	211	190	232	230	229	182	19,98889	212	9,41%	X
ADE016	615	605	738	696	792	667	65,82996	686	9,60%	X
9DC8BD	279	272	334	326	368	329	33,11092	318	10,41%	Y
279886	707	783	963	902	780	785	85,76713	820	10,46%	Y
D65CAD	394	418	484	478	540	421	49,72731	456	10,91%	Y
D65CA6	255	237	272	305	326	250	31,55639	274	11,51%	Y
A8EA2E	231	231	293	237	219	194	29,81284	234	12,73%	Y
ADDFD8	283	299	352	327	364	414	43,38747	340	12,77%	Y
ADE00A	306	362	387	286	392	297	43,39995	338	12,83%	Y
396391	813	559	777	613	716	647	89,69903	688	13,05%	Y
ADDFDA	167	153	221	207	203	229	27,60233	197	14,04%	Y
9DF2A2	221	341	247	314	297	262	40,94576	280	14,61%	Y
421657	331	408	540	402	418	444	62,29076	424	14,70%	Y
ADE01F	480	444	661	545	665	535	83,44859	555	15,04%	Y
410889	514	457	391	330	367	370	62,01456	405	15,32%	Y
B44660	204	252	244	242	255	348	43,80164	258	17,01%	Y
259532	238	192	326	236	247	216	41,44776	243	17,09%	Y
472269	583	354	360	428	431	364	79,42082	420	18,91%	Y
316625	365	264	315	236	258	204	52,69619	274	19,26%	Y
9DF2A3	252	370	535	444	386	389	84,83906	396	21,42%	Y
B49C2A	288	358	525	280	379	272	87,89893	350	25,09%	Z
C6596B	462	731	786	913	845	1.226	227,685	827	27,53%	Z
9F0420	223	371	339	477	582	421	112,0691	402	27,87%	Z
D14532	541	269	417	269	302	229	108,1271	338	32,01%	Z
A96FD9	134	404	189	290	280	175	90,26566	245	36,79%	Z
A89010	970	2.388	1.353	1.387	972	817	523,2325	1.315	39,80%	Z
D63356	163	182	545	216	255	251	128,0035	269	47,64%	Z
D24145	608	167	184	153	211	247	157,8667	262	60,33%	Z
D033F7	823	231	244	212	231	253	219,7981	332	66,14%	Z
B8EBA5	0	0	229	289	350	339	147,5211	201	73,33%	Z
A7FA71	2.511	958	663	434	660	524	713,0415	958	74,40%	Z
D033F9	1.846	488	424	391	461	493	520,9477	684	76,18%	Z
9F041D	115	713	183	177	1.448	736	470,7703	562	83,77%	Z
B3CD80	66	193	57	848	117	701	319,9811	330	96,87%	Z
DD81EA	0	0	325	350	325	0	166,8749	167	100,12%	Z
290344	881	155	46	58	47	29	306,1245	203	151,05%	Z

Izvor: [18]

5.3.Provedba unakrsne ABC/XYZ analize

Provedenom ABC i XYZ analizom vrši se nova unakrsna analiza, prikazana Tablicom 5. Kako je ranije spomenuto artikli se dijele u devet skupina prema kojima konačno možemo odrediti kakva bi trebala biti politika nabavljanja artikala i držanja zaliha tvrtke.

Tablica 5. Usporedba ABC i XYZ analize artikala

Int. No.	Udio u prodaji	ABC	XYZ	Int. No.	Udio u prodaji	ABC	XYZ
D033F9	23,31%	A	Z	9DF2A2	0,79%	C	Y
D14532	14,50%	A	Z	396391	0,76%	C	Y
D033F7	8,87%	A	Z	ADE00A	0,73%	C	Y
D24145	8,00%	A	Z	259532	0,72%	C	Y
C6596B	5,63%	A	Z	B44660	0,70%	C	Y
D65CA6	5,33%	A	Y	ADDFDA	0,65%	C	Y
B8EBA5	4,96%	B	Z	ADDFE3	0,64%	C	X
D65CAD	2,47%	B	Y	9DF2A3	0,58%	C	Y
A7FA71	2,37%	B	Z	9B3C88	0,57%	C	X
ADE016	1,91%	B	Y	9F041D	0,56%	C	Z
9DC8BD	1,75%	B	Y	B49C2A	0,53%	C	Z
A89010	1,47%	B	Z	396392	0,41%	C	X
ADDFDB	1,29%	B	X	B3CD80	0,39%	C	Z
421657	1,29%	B	Y	396389	0,39%	C	X
A8EA2E	1,17%	B	Y	D63356	0,38%	C	Z
ADE01F	1,10%	B	Y	316625	0,34%	C	Y
9F0420	0,99%	B	Z	257284	0,32%	C	X
410889	0,97%	B	Y	DD81EA	0,27%	C	Z
B68D93	0,94%	B	X	472269	0,08%	C	Y
290344	0,89%	B	Z	A96FD9	0,05%	C	Z
ADDFD8	0,89%	C	Y	279886	0,05%	C	Y

Izvor: [18]

Konačnom usporedbom artikle dijelimo u tri glavne skupine.

Prva skupina u teoriji sadrži AX, AY i BX artikle. U ovom primjeru ne postoje AX artikli. AY artikli i BX artikli označeni su bijelom bojom u tablici 5. te se preporučuje posvetiti im veliku pozornost u planiranju zaliha. AY artikli nose velik udio u ukupnoj

vrijednosti, no njihova potrošnja je diskontinuirana sa srednjom točnošću prognoze prodaje. Kako tvrtka ne bi ostvarivala gubitke u poslovanju, s jedne strane zbog manjka zaliha u skladištu, a s druge prevelikom količinom zaliha koje generiraju troškove njihova držanja, za AY skupinu preporuča se držati optimalnu količinu zaliha, temeljenu na povijesnim podacima potražnje i ugovoriti kontinuirano opskrbljivanje. BX artikli nose srednji udio u ukupnoj vrijednosti i veliku točnost prognoze potreba. Za BX artikle potrebno je ugovoriti kontinuiranu opskrbu s dobavljačem.

Druga skupina uključuje AZ, BY i CX artikle prikazane sivom bojom u Tablici 5. Preporučuje se posvetiti im srednju pozornost prilikom planiranja. Iz tablice je vidljivo kako AZ artikli nose najveći udio u ukupnoj prodaji, čak 60,3 %, no karakterizira ih također i povremena potrošnja s malom točnošću prognoze. Iz tog razloga ne preporuča se držanje zaliha, nego organizirati pojedinačnu opskrbu prema potrebama korisnika. CX artikle karakterizira kontinuirana potrošnja, s velikom točnošću prognoze, a zbog njihovog malog udjela u vrijednosti, mogu postojati maksimalne zalihe, koje neće uzrokovati gubitke za poslovanje pri držanju zaliha.

U trećoj skupini nalaze se BZ, CY i CZ artikli. Skupina je označena ružičastom bojom u tablici 5. Karakterizira ju maleni udio u ukupnoj vrijednosti, te povremena potrošnja i srednja do mala točnost prognoze, pa stoga im se posvećuje izrazito mala pozornost pri optimiranju zaliha. Zbog malih troškova držanja zaliha preporučuje se artikle nabavljati jednom godišnje.

ZAKLJUČAK

Upravljanje zalihama u bilo kojem pogledu vodeća je zadaća svake tvrtke. Temeljni cilj logističkih tvrtki je smanjiti količinu zaliha na najmanju razinu, a da pri tome njihovo poslovanje ne bude ugroženo. Učinkovito upravljanje zalihama bazira se na primjenama suvremenih modela i analiza, primjeni naprednog informacijskog sustava, edukaciji i svijesti svih zaposlenih o potrebi držanja što nižih zaliha što za sobom povlači kvalitetnu primjenu metoda planiranja ponude i potražnje.

Pojedini modeli optimizacije pružaju mogućnosti iskoristive u slučajevima nestabilnosti kretanja cijena na tržištu, kao što je povećanje cijena prijevoza ili skladištenja.

Među važnije suvremene modele svrstan je model ERP, poslovni računalni program koji integrira različite upravljačke i informacijske sustave unutar tvrtke. Značajniju ulogu ima njegova primjena u automobilske industriji, odnosno postprodaji automobilske industrije. Bez primjene informacijskog sustava, s obzirom na broj artikala, optimizacija zaliha postprodaje automobilske industrije, bila bi izrazito zahtjevna pa čak i ne efikasna.

Kako bi se održala konkurentnost na tržištu potrebno je stalno razvijati nove i unaprjeđivati postojeće poslovne modele kojima se pojednostavljuje i racionalizira poslovanje.

Analiza optimizacije zaliha koja uzima u obzir kriterije ukupne vrijednosti i kontinuiteta potrošnje je unakrsna ABC/XYZ analiza. Prema studiji slučaja ABC/XYZ analize nad stvarnim podacima možemo zaključiti kako artikli koji se drže na zalihi nisu uvijek nužno oni koji donose najveću zaradu, svaki artikl treba pomno ispitati temeljem statistika prethodnih godina. Nakon što se utvrdi pozicija artikala u analizama, može se provesti kvalitetna optimizacija zaliha.

Literatura

- [1] Habek, M. i skupina autora: Upravljanje zalihama i skladišno poslovanje, RRIF Plus, Zagreb, 2002., str. 199., 313.
- [2] Zelenika, R., Pupovac, D.: Menadžment logističkih sustava, Ekonomski fakultet Sveučilišta u Rijeci, IQPLUS d.o.o. Kastav, 2008.
- [3] <https://repozitorij.fpz.unizg.hr/islandora/object/fpz%3A15/datastream/PDF/view> (preuzeto: srpanj 2017.), str. 17
- [4] <http://www.efos.unios.hr/repec/osi/bulimm/PDF/BusinessLogisticsinModernManagement11/blimm1104.pdf> (preuzeto: srpanj 2017.)
- [5] Ferišak, V.: Nabava: politika, strategija, organizacija, management, Tisak Grafos, Zagreb, 2002., str. 285. – 288., 291., 294., 295., 505., 506., 525. – 533.
- [6] Božić, D.: Nastavni materijali iz kolegija „Upravljanje zalihama“, Fakultet prometnih znanosti, Zagreb, 2017., URL: <http://e-student.fpz.hr/> (preuzeto: srpanj 2017.)
- [7] Šafran, M.: Nastavni materijali iz kolegija „Upravljanje zalihama“, Predavanje_1, Fakultet prometnih znanosti, Zagreb, 2017., URL: <http://e-student.fpz.hr/> (preuzeto: srpanj 2017.)
- [8] Ferišak, V., Stihović L.: Nabava i materijalno poslovanje, Informator, Zagreb, 1989., str. 363. – 365.
- [9] Čefko, D.: Mogućnosti optimiranja zaliha u opskrbnom lancu, završni rad, Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, str. 12., 14., 35., URL: <https://repozitorij.fpz.unizg.hr/islandora/object/fpz%3A29/datastream/PDF/view> (srpanj 2017.)
- [10] Ivaković, Č., Stanković, R., Šafran, M.: Špedicija i logistički procesi, Fakultet prometnih znanosti, Sveučilište u Zagrebu, 2010., str. 269. – 271.
- [11] Horvat, D.: Unaprjeđenje upravljanja zalihama u maloprodaji, završni rad, Sveučilište Sjever, Varaždin, 2015., URL: <https://repozitorij.unin.hr/islandora/object/unin%3A143/datastream/PDF/view>, str. 22. (srpanj 2017.)
- [12] <http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+24&parent=NULL&page=Lean%20menadzment> (srpanj 2017.)

[13] http://predmet.singidunum.ac.rs/pluginfile.php/3950/mod_folder/content/0/IX_Odrz_Rezer_delovi_Troskovi_PP.ppt?forcedownload=1 (srpanj 2017.)

[14] Novotny, D.: Prodiranje novih i internetskih tehnologija kao pokretača gospodarskog rasta u javnom i privatnom sektoru Republike Hrvatske, Ekonomski pregled, Vol.57, No.5-6, srpanj 2006., str. 367., URL: <http://hrcak.srce.hr/8347> (srpanj 2017.)

[15] Gajšak, M.: Projektiranje informacijskih sustava, ERP stanje i trendovi, seminarski rad, Sveučilište u Zagrebu, Fakultet elektrotehnike i računalstva, 2006., URL: http://www.academia.edu/11289036/PROJEKTIRANJE_INFORMACIJSKIH_SUSTAVA_ERP_STANJE_I_TRENDOVI (srpanj 2017.)

[16] <http://www.eska.hr/proizvodi/microsoft-dynamics-nav/Navision/82/87/0/HR> (preuzeto: srpanj 2017.)

[17] <http://www.eazystock.com/blog/demand-forecasting/2016/05/18/4-ways-to-stay-competitive-in-automotive-parts-distribution/> (preuzeto: srpanj 2017.)

[18] Službeni podaci tvrtke Inter Cars Hrvatska d.o.o.

Popis kratica

ABC	analiza koja pomaže pri optimiranju zaliha
APS	(eng. Advanced Planning Systems) napredno logističko planiranje
CV	koeficijent varijacije
DRP	(eng. Distribution Resource Planning) planiranje resursa distribucije
EOQ	(eng. Economic Order Quantity) ekonomska količina nabave
ERP	(eng. Enterprise Resource Planning) planiranje resursa poduzeća
JC	jedinična cijena artikla
JIT	(eng. Just in Time) sustav „točno na vrijeme“
KUM	kumulativna vrijednost
MRP I	(eng. Material Requirement Planning) model planiranja materijalnih potreba
MRP II	(eng. Manufacturing Resource Planning) planiranje resursa proizvodnje
PP	prosječna potražnja po artiklu
SD	standardna devijacija
UP	ukupna prodaja po artiklu
UUP	udio u ukupnoj prodaji po artiklu
XYZ	analiza koja pomaže pri optimiranju zaliha

Popis slika

Slika 1. Kretanje zaliha u kontinuiranom sustavu nadzora razine zaliha, Q - model kontinuiranom sustavu nadzora.....	4
Slika 2. Kretanje zaliha u periodičnom sustavu nadzora razine zaliha, P – model.....	5
Slika 3. Kretanje troškova zaliha u jedinici vremena.....	7
Slika 4. Klasičan Pareto dijagram	13
Slika 5. Grafički prikaz XYZ analize.....	16
Slika 6. Izračun ukupne zarade u Microsoft Excelu.....	25
Slika 7. Izračun kumulativne vrijednosti u Microsoft Excelu.....	25
Slika 8. Izračun standardne devijacije u Microsoft Excelu	28
Slika 9. Izračun prosječne potražnje po artiklu u Microsoft Excelu	29

Popis tablica

Tablica 1. Matrični prikaz kombinacije rezultata ABC i XYZ analize.....	17
Tablica 2. Polugodišnja prodaja 42 artikla, sa njihovom jediničnom cijenom	23
Tablica 3. Kategorizacija 42 artikla prema ABC analizi.....	27
Tablica 4. Kategorizacija 42 artikla prema XYZ analizi.....	30
Tablica 5. Usporedba ABC i XYZ analize artikala.....	31



Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj _____ završni rad

isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu _____ završnog rada

pod naslovom **Prijedlozi optimiranja zaliha postprodaje automobilske industrije**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 22.8.2017 _____

Student/ica: _____
(potpis)



University of Zagreb
Faculty of Transport and Traffic Sciences
10000 Zagreb
Vukelićeva 4

DECLARATION OF ACADEMIC INTEGRITY AND CONSENT

I declare and confirm by my signature that this _____ završni rad
is an exclusive result of my own work based on my research and relies on published literature,
as can be seen by my notes and references.
I declare that no part of the thesis is written in an illegal manner,
nor is copied from unreferenced work, and does not infringe upon anyone's copyright.
I also declare that no part of the thesis was used for any other work in
any other higher education, scientific or educational institution.
I hereby confirm and give my consent for the publication of my _____ završnog rada
titled Automotive Parts Inventory Optimization Options

on the website and the repository of the Faculty of Transport and Traffic Sciences and
the Digital Academic Repository (DAR) at the National and University Library in Zagreb.

In Zagreb, 05 September 2017

Student: 
(signature) 